

文章编号 :1007-649X(2000)04-0033-03

子波神经网络在故障诊断中的应用研究

时斌, 孙惠国, 薛斌党

(郑州工业大学机械与电子工程学院, 河南 郑州 450002)

摘要:根据旋转机械常见的故障类型和故障信号时域采样数据, 以子波空间作为模式识别的特征空间, 采用信息熵为代价函数的神经网络学习算法, 由子波神经网络对故障进行学习和诊断。实验结果表明, 子波神经网络的故障诊断方法在不了解故障信号频率结构的情况下, 即可对平稳和非平稳故障信号进行诊断, 适于设备在线监测及设备的巡检。

关键词:子波神经网络; 故障诊断; 信息熵

中图分类号: TP 18; TP 206.3 文献标识码:A

子波神经网络是基于子波分析而构造出的一类新型前馈网络, 也可以看作是以子波函数为基础的一种新型函数联接神经网络。它以子波空间作为模式识别的特征空间, 通过将子波基与信向量的内积进行加权和来实现信号的特征提取, 结合了子波变换良好的时频局域化性质及传统神经网络的自学习功能, 具有较强的逼近与容错能力^[1], 因而在许多领域得到应用。文献[2]把子波神经网络应用于原子半径的预报, 并取得了较好的效果。文献[3]则研究了基于子波神经网络的非线性动力系统辨识的方法。文献[1, 2]中子波神经网络的学习算法是一般的反向传播算法, 这种算法具有收敛速度慢, 可能陷入局部最小等缺点, 本文采用的以信息熵为代价函数的神经网络学习算法^[3]加快了网络的收敛速度, 并在一定程度上抑制了学习误差的振荡。本文以故障信号时域采样数据构造故障模式, 研究了子波神经网络的故障诊断方法, 取得了较好的效果。

1 子波神经网络学习算法

采用的子波神经网络见图1。时域采样数据经投影压缩后作为子波神经网络隐层的输入。

设输出层第 k 个($k=1, 2, \dots, K$)结点, 隐层第 j 个($j=1, 2, \dots, J$)结点, 输入层第 i 个($i=1, 2, \dots, I$)结点, 第 p ($p=1, 2, \dots, P$)组样本的输入、输出分别由 $I_k^p, I_j^p, I_i^p (= O_i^p)$ 和 O_k^p, O_j^p, O_i^p 表

示, 则

$$I_k^p = \sum_{j=1}^J V_{jk} O_j^p, \quad I_j^p = \sum_{i=1}^I W_{ij} O_i^p; \quad (2)$$

$$O_k^p = f(I_k^p), \quad O_j^p = f\left(h\left(\frac{I_j^p - b_j}{a_j}\right)\right), \quad (3)$$

式中, V_{jk}, W_{ij} 为相邻两层神经元的连接权值; $f(\cdot)$ 为非线性激励函数, 本文中 $f(\cdot)$ 取 Sigmoid 函数。其中, 母子波 $h(t) = \cos(1.75t) \exp(-t^2/2)$ 为 Gaussian 包络振荡函数。

代价函数取信息熵函数^[4]

$$E^p = - \sum_{k=1}^K [F_k^p \lg(O_k^p) + (1 - T_k^p) \lg(1 - O_k^p)], \quad (4)$$

式中, T_k^p 为第 k 个结点的期望输出。

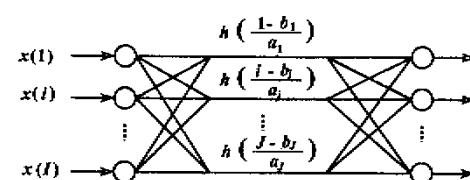


图1 子波神经网络结构

网络的具体学习算法如下:

(1) 网络参数的初始化。子波的伸缩因子 a_j , 平移因子 b_j , 以及网络连接权值 W_{kj}, W_{ji} 赋以随机的初始值;

(2) 输入学习样本及相应的期望输出 T_k^p ;

(3) 分别计算隐层及输出层的输入和输出;

收稿日期 1999-12-10; 修订日期 2000-06-13

基金项目 河南省科技攻关项目(98112037)

作者简介 时斌(1964-)男, 河南省郑州市人, 郑州工业大学副教授, 硕士, 主要从事机械故障诊断与计算机应用
万方数据的研究。

(4) 计算瞬时梯度向量为

$$\delta_{V_{jk}} = \frac{\partial E_k^p}{\partial V_{jk}} = (T_k^p - O_k^p) \cdot O_j^p; \quad (5)$$

$$\delta_{W_{ij}} = \frac{\partial E_k^p}{\partial W_{ij}} = \sum_{k=1}^K (T_k^p - O_k^p) \cdot V_{jk} \cdot f(h(t_1)) \cdot$$

$$(1 - f(h(t_1))) \cdot \frac{\partial h(t_1)}{\partial I_j^p} \cdot O_i^p; \quad (6)$$

$$\delta_{a_j} = \frac{\partial E_k^p}{\partial a_j} = \sum_{k=1}^K (T_k^p - O_k^p) \cdot V_{jk} \cdot f(h(t_1)) \cdot$$

$$(1 - f(h(t_1))) \cdot \frac{\partial h(t_1)}{\partial a_j}; \quad (7)$$

$$\delta_{b_j} = \frac{\partial E_k^p}{\partial b_j} = \sum_{k=1}^K (T_k^p - O_k^p) \cdot V_{jk} \cdot f(h(t_1)) \cdot$$

$$(1 - f(h(t_1))) \cdot \frac{\partial h(t_1)}{\partial b_j}; \quad (8)$$

其中,

$$\frac{\partial h(t_1)}{\partial I_j^p} = -1.75 \sin(1.75t_1) \exp(-t_1^2/2) \cdot \frac{1}{a_j} -$$

$$\cos(1.75t_1) \exp(-t_1^2/2) \cdot \frac{t_1}{a_j}; \quad (9)$$

$$\frac{\partial h(t_1)}{\partial a_j} = 1.75 \sin(1.75t_1) \exp(-t_1^2/2) \cdot \frac{t_1}{a_j} +$$

$$\cos(1.75t_1) \exp(-t_1^2/2) \cdot \frac{t_1^2}{a_j}; \quad (10)$$

$$\frac{\partial h(t_1)}{\partial b_j} = 1.75 \sin(1.75t_1) \exp(-t_1^2/2) \cdot \frac{1}{a_j} +$$

$$\cos(1.75t_1) \exp(-t_1^2/2) \cdot \frac{t_1}{a_j}, \quad (11)$$

(5) 误差反向传播为

$$\begin{cases} \Delta V_{jk}^{\text{new}} = -\alpha \delta_{V_{jk}} + \beta \Delta V_{jk}^{\text{old}}, \\ \Delta W_{ij}^{\text{new}} = -\alpha \delta_{W_{ij}} + \beta \Delta W_{ij}^{\text{old}}; \end{cases} \quad (12)$$

$$\begin{cases} \Delta a_j^{\text{new}} = -\alpha \delta_{a_j} + \beta \Delta a_j^{\text{old}}; \\ \Delta b_j^{\text{new}} = -\alpha \delta_{b_j} + \beta \Delta b_j^{\text{old}}; \end{cases} \quad (13)$$

修改网络参数 a_j, b_j, V_{jk}, W_{ij} , 即

$$V_{jk}^{\text{new}} = V_{jk}^{\text{old}} + \Delta V_{jk}^{\text{old}}; \quad (14)$$

$$W_{ij}^{\text{new}} = W_{ij}^{\text{old}} + \Delta W_{ij}^{\text{old}}; \quad (15)$$

$$a_j^{\text{new}} = a_j^{\text{old}} + \Delta a_j^{\text{old}}; \quad (16)$$

$$b_j^{\text{new}} = b_j^{\text{old}} + \Delta b_j^{\text{old}}. \quad (17)$$

(6) 当代价函数值小于预先设定的某个值, 则停止网络的学习, 否则返回步骤(2).

2 故障诊断应用

根据旋转机械在工作时可能出现的故障类型, 以转子实验数据模拟几种故障由子波神经网络

进行学习和诊断(其中转子裂纹故障为实际机组故障). 几种故障的时域波形如图 2~7 所示. 测取时域内 128 个数据点(整周期采样, 每周采 32 个点)作为故障模式, 组成标准故障样本, 对子波神经网络进行训练. 网络的训练结果如表 1 所示.

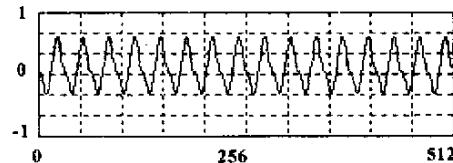


图 2 不平衡时的时域波形

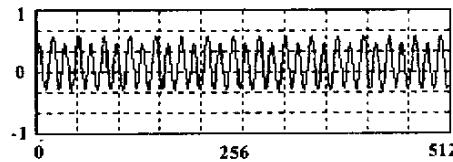


图 3 不对中时的时域波形

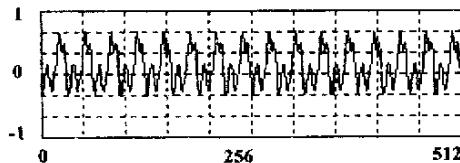


图 4 基础松动时的时域波形

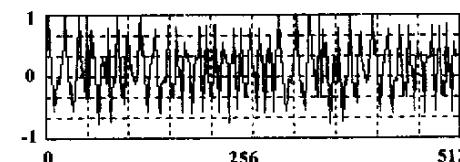


图 5 油膜振荡时的时域波形

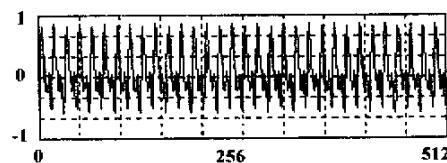


图 6 动静件碰摩时的时域波形

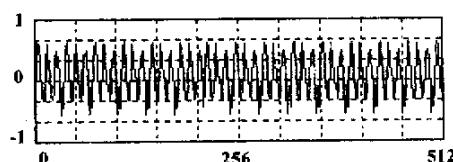


图 7 转子横向裂纹时的时域波形

从网络训练结果可以看出, 子波神经网络对故障的诊断精度是比较高的, 可以用于故障诊断. 为了验证训练后的子波神经网络的故障诊断精

度,以不对中和转子横向裂纹故障信号人为地加上随机噪声作为测试信号构造测试故障模式,测试信号如图8、图9所示,子波神经网络对测试信号的诊断结果如表2所示。

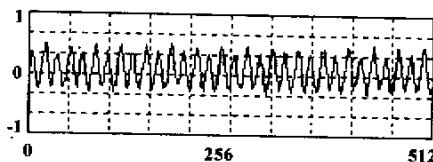


图8 测试信号1

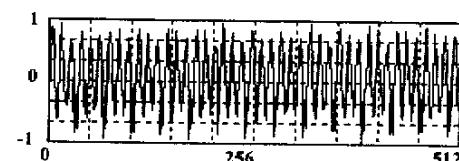


图9 测试信号2

从表2的测试结果可以看出,子波神经网络的诊断结果与实际是相符的,因此可以用于故障诊断。

表1 网络训练结果

故障类型	结点1	结点2	结点3	结点4	结点5	结点6
不平衡	0.93452	0.02912	0.01748	0.00077	0.03897	0.01851
不对中	0.04189	0.93883	0.04612	0.03074	0.00005	0.02464
基础松动	0.02564	0.03914	0.93511	0.01320	0.03717	0.00040
油膜振荡	0.00274	0.01702	0.01333	0.91126	0.06154	0.04049
动静件碰摩	0.03748	0.00036	0.04052	0.06880	0.91723	0.02286
转子横向裂纹	0.01960	0.03084	0.00013	0.03606	0.02040	0.94662

表2 测试结果

类型	不平衡	不对中	松动	油膜振荡	动静件碰摩	转子横向裂纹
模式1	0.02116	0.81753	0.00416	0.02529	0.0001	0.02106
模式2	0.02005	0.02931	0.00001	0.07127	0.00214	0.76748

3 结束语

本文结合子波变换良好的时频局域化性质及传统神经网络的自学习功能,根据信号时域采样数据,在不了解其频率组成的情况下,由子波神经网络对故障进行了诊断,诊断结果说明子波神经网络故障诊断方法是可行的。

参考文献:

[1] 焦李成.神经网络应用与实现[M].西安:西安电子

科技大学出版社,1996.237-252.

- [2] 江涌 刘磊 蔡文生等.小波神经网络用于原子半径的研究[J].中国科技大学学报,1998,28(6):644-651.
- [3] TANG Yong-hong. Nonlinear dynamic system identification based on wavelet neural network[J]. Journal of Guilin Institute of Electronic Technology,1999,19(1):1-6.
- [4] 孙惠国.信息熵为代价函数的神经网络算法及诊断应用[J].振动工程学报,1998,11(增刊):135-138.

Application Research of Wavelet Neural Network to Fault Diagnosis

SHI Bin, SUN Hui-guo, XUE Bin-dang

(College of Mechanical & Electronic Engineering Zhengzhou University of Technology Zhengzhou 450002, China)

Abstract This paper proposes a wavelet neural network for fault diagnosis. According to the faults of rotary machinery, based on wavelet space, the neural networks for fault diagnosis are trained with fault signals in time domain. The learning algorithm is based on entropy cost function. The result indicates that wavelet neural networks can diagnose stationary and non-stationary fault signals without analyzing the frequency structure of fault signals, and this method can be applied to going on the tour of monitoring for machinery on the spot.

Key words wavelet neural networks; fault diagnosis; entropy